

Dự báo biến dạng từ biến của cấu kiện bê tông cốt thép bằng phương pháp học máy

Predicting long-term deflections of reinforced concrete members using
machine-learning approach

Trần Xuân Linh^{a,b*}
Tran Xuan Linh^{a,b*}

^aKhoa Xây dựng, Trường Đại học Duy Tân, Đà Nẵng, Việt Nam

^aFaculty of Civil Engineering, Duy Tan University, Da Nang, 550000, Vietnam

^bViện Nghiên cứu và Phát triển Công nghệ Cao, Đại học Duy Tân, Đà Nẵng, Việt Nam

^bInstitute of Research and Development, Duy Tan University, Da Nang, 550000, Vietnam

(Ngày nhận bài: 03/07/2023, ngày phản biện xong: 09/07/2023, ngày chấp nhận đăng: 07/12/2023)

Tóm tắt

Nghiên cứu này ứng dụng mô hình LightGBM để dự đoán biến dạng từ biến của các cấu kiện bê tông cốt thép. Mô hình được huấn luyện và thử nghiệm dựa trên bộ dữ liệu gồm 217 mẫu thí nghiệm sưu tầm từ nguồn tài liệu hiện có. 21 yếu tố ảnh hưởng được chọn làm biến độc lập của mô hình. Kết quả tính toán sau 30 lần chạy ngẫu nhiên cho thấy thuật toán LightGBM có thể đạt được hiệu suất dự đoán tốt với giá trị căn bậc hai của sai số bình phương trung bình là 9.84, sai số phần trăm tuyệt đối trung bình là 21.16% và hệ số xác định là 0.90. Các chỉ số này cũng tỏ ra tốt hơn so với các mô hình khác. Do đó, mô hình LightGBM có thể được dùng như là một công cụ trợ giúp các kỹ sư dự đoán biến dạng từ biến của các cấu kiện bê tông cốt thép như dầm và sàn một phương.

Từ khóa: Học máy có giám sát; thuật toán LightGBM; trí tuệ nhân tạo; biến dạng từ biến; cấu kiện bê tông cốt thép.

Abstract

This study applies the LightGBM model to predict long-term deflections of reinforced concrete members. The proposed model is constructed and tested by a dataset consisting of 217 experiments collected from existing literature. 21 factors have been selected as independent variables of the model. The calculation results after 30 random runs of the model point out that the LightGBM algorithm can attain good predictive performances with average root mean square error of 9.84, average mean absolute percentage error of 21.16% and average coefficient of determination of 0.90. These parameters also proved superior to other models. Therefore, the LightGBM model can assist engineers in predicting long-term deflections of reinforced concrete members, including beams and one-way slabs.

Keywords: Supervised machine learning; LightGBM algorithm; artificial intelligence; long-term deflection; reinforced concrete members.

*Tác giả liên hệ: Trần Xuân Linh

Email: tranxuanlinh@duytan.edu.vn

1. Giới thiệu

Một trong những xu hướng của ngành xây dựng trong thời kỳ hiện nay là việc ứng dụng ngày càng nhiều các kết cấu mảnh, nhẹ và có nhịp dài. Điều này giúp làm giảm trọng lượng bản thân, mở rộng không gian sử dụng và tăng tính thẩm mỹ của các công trình xây dựng. Việc tính toán và giám sát biến dạng của các cấu kiện này đóng vai trò quan trọng để đảm bảo tính ổn định cũng như khả năng hoạt động theo đúng công năng đề ra trong quá trình thiết kế của các công trình. Đối với các công trình bê tông cốt thép (BTCT), biến dạng tăng theo thời gian (biến dạng từ biến) gây ảnh hưởng không nhỏ đến công năng sử dụng và tuổi thọ của chúng. Nghiên cứu [1] chỉ ra rằng, biến dạng từ biến của các phần tử mảnh chịu uốn như dầm và sàn BTCT có thể tăng gấp 3 đến 4 lần lớn hơn biến dạng tức thời. Biến dạng từ biến tăng cao kéo theo sự phát triển và mở rộng các vết nứt có thể dẫn đến hậu quả phá hủy các cấu kiện BTCT nói riêng và tổng thể công trình nói chung [1]. Vì vậy, cần phải có các biện pháp đánh giá biến dạng từ biến của cấu kiện BTCT ngay từ giai đoạn thiết kế nhằm mục đích giữ cho công trình hoạt động ổn định và an toàn.

Tuy nhiên, đây là một nhiệm vụ khó khăn do ảnh hưởng phi tuyến tính của nhiều yếu tố. Các yếu tố này có thể không phụ thuộc thời gian như các tính chất hình học kết cấu, tính chất cơ lý của thép và bê tông hoặc phụ thuộc thời gian như tuổi của bê tông, thời gian duy trì tải trọng, mức độ tải trọng tác dụng và mức độ rạn nứt [2]. Trong đó, tuổi của bê tông là yếu tố gây nên những ảnh hưởng đáng kể đến độ lớn của biến dạng từ biến [2, 3].

Một số nghiên cứu [4-14] đã đề xuất các phương pháp thực nghiệm và các phương pháp rút gọn (đưa ra các giả thiết đơn giản hóa hoặc bỏ qua một số yếu tố ảnh hưởng). Các phương pháp thực nghiệm đòi hỏi khá nhiều thời gian và chi phí thực hiện vì phải theo dõi và ghi lại biến

dạng từ biến qua nhiều năm. Trong khi các phương pháp đơn giản hóa lại không tính đến vai trò của một số yếu tố ảnh hưởng. Điều này dẫn đến kết quả tính toán có thể sai lệch so với thực tế.

Hiện nay, các tiêu chuẩn thiết kế như ACI 318 [15] và Eurocode 2 [16] được các kỹ sư sử dụng khá phổ biến để xác định biến dạng từ biến của cấu kiện BTCT [8]. Các tiêu chuẩn này thường chỉ giới hạn cho một số trường hợp tính toán đơn giản có kết cấu và tải trọng tương tự nhau [17]. Ngoài ra, các tiêu chuẩn thiết kế này bỏ qua ảnh hưởng của một số yếu tố quan trọng như các thông số hình học và cơ lý [10, 18].

Do đó, việc phát triển và ứng dụng các phương pháp phi tuyến tính có thể tính đến nhiều thuộc tính ảnh hưởng là điều rất cần thiết. Cùng với sự phát triển mạnh mẽ của khoa học công nghệ nói chung và khoa học máy tính nói riêng, các mô hình học máy đang ngày càng được ứng dụng nhiều hơn trong các lĩnh vực khác nhau, đặc biệt là trong lĩnh vực xây dựng và vật liệu. Các mô hình học máy là một nhánh của ngành khoa học Trí tuệ nhân tạo. Các mô hình này có một số ưu điểm như có thể xử lý những bài toán có độ phức tạp cao với nhiều yếu tố phi tuyến, tính đa năng, hiệu quả tính toán cao với chi phí thấp... Có thể kể ra một số nghiên cứu ứng dụng trí tuệ nhân tạo trong lĩnh vực này như: dự báo phá hủy kết cấu [19]; dự đoán độ võng của dầm bê tông [20]; dự đoán vết nứt trong dầm BTCT [21]; dự báo biến dạng từ biến của bê tông xanh [22]; sử dụng mô hình học máy XGBoost để dự đoán biến dạng từ biến của các dầm và sàn BTCT [23]; đánh giá khả năng chọc thủng sàn BTCT [24]; dự đoán cường độ chịu cắt của các kết cấu BTCT [25]...

Trong bài báo này, chúng tôi sẽ đề xuất ứng dụng mô hình học máy LightGBM để dự đoán biến dạng từ biến của các cấu kiện BTCT dầm và sàn một phương dựa trên bộ dữ liệu gồm 217 mẫu thí nghiệm được sưu tầm từ các công trình nghiên cứu trước đó.


Các phần còn lại của bài báo được trình bày theo thứ tự như sau: mục tiếp theo trình bày phương pháp nghiên cứu và mô tả tập dữ liệu thực nghiệm; các kết quả tính toán, so sánh với các mô hình khác và thảo luận về hiệu suất của thuật toán LightGBM trình bày ở mục 3; phần cuối bài báo là các kết luận và hướng nghiên cứu mở rộng của đề tài.

2. Phương pháp nghiên cứu


2.1. Mô hình LightGBM

LightGBM là một thuật toán được phát triển bởi tổ chức *Microsoft Research Asia* dựa trên phương pháp cây quyết định tăng cường (*Gradient Boosting Decision Tree (GBDT)*) [26]. Một trong những ưu điểm của mô hình này là hiệu quả tính toán cao, đặc biệt đối với các bài toán dự đoán với số lượng lớn dữ liệu đầu vào.

Trong khi đa số các mô hình sử dụng thuật toán cây quyết định phát triển cây theo cấp độ (*Level-wise tree growth*) (Hình 1). Thuật toán LightGBM là phương pháp dựa trên biểu đồ và chiến lược tăng trưởng theo chiều lá của cây (*trees leaf-wise growth strategy*) (Hình 2). Chiến lược tăng trưởng theo chiều lá chỉ phân tách các lá có mức thu thập thông tin lớn nhất trên cùng một lớp nhằm tăng tốc độ huấn luyện mô hình và giảm mức tiêu thụ bộ nhớ [27, 28]. Ngoài ra, giới hạn độ sâu tối đa của cây cũng được quy định trong quá trình sinh trưởng của cây nhằm hạn chế hiện tượng khớp quá mức (*over-fitting*) [27]. Trong bài báo này chúng tôi sử dụng các tham số sau cho mô hình LightGBM: số lá tối đa trên một cây '*num_leaves*' = 10; đối tượng '*objective*' = '*regression*' và phương pháp '*boosting*' = '*gbdt*'.



Hình 1. Chiến lược tăng trưởng theo độ sâu của cây



Hình 2. Chiến lược tăng trưởng theo chiều lá của cây

2.2. Bộ dữ liệu thực nghiệm

Trong nghiên cứu này, chúng tôi sử dụng một bộ dữ liệu thực nghiệm gồm 217 mẫu được sưu tầm từ công trình nghiên cứu trước đó [29]. Bộ dữ liệu được tổng hợp từ 29 chương trình nghiên cứu khác nhau. Các thí nghiệm đã đo đạc và ghi lại biến dạng tức thời và biến dạng từ biến của các cấu kiện bê tông cốt thép như dầm và sàn một phương. Có nhiều yếu tố ảnh hưởng đến biến dạng từ biến được mô tả chi tiết trong tài liệu [29] như các tính chất hình học của kết cấu, hàm lượng thép, điều kiện môi trường, cường độ

bê tông, giá trị tải trọng và sự phân bố ngoại lực, thời gian tải trọng duy trì, thời điểm đo biến dạng... Điều này cho thấy đây là bài toán đa biến và tương đối phức tạp. Tổng cộng có 21 yếu tố được chọn làm biến độc lập (biến đầu vào) của mô hình LightGBM để dự đoán biến phụ thuộc (biến đầu ra) là biến dạng từ biến của dầm và sàn bê tông cốt thép [29].

3. Kết quả tính toán và thảo luận

Bộ dữ liệu thô sẽ được chuẩn hóa bằng phép biến đổi dữ liệu điểm Z (*Z-score data transformation*) (biểu thức (1)) trước khi được

sử dụng để huấn luyện và kiểm nghiệm mô hình. Mục đích của phép chuẩn hóa dữ liệu là nhằm giảm tác động tiêu cực của các biến số có giá trị lớn. Để đánh giá hiệu suất tính toán của mô hình, nghiên cứu này sử dụng các thông số gồm căn bậc hai của sai số toàn phương trung bình (*RMSE*), sai số phần trăm tuyệt đối trung bình (*MAPE*) và hệ số xác định (R^2) (biểu thức 2-4). Sử dụng nhiều tiêu chí khác nhau sẽ giúp đánh giá tốt hơn những ưu và nhược điểm của mô hình được đề xuất ở các khía cạnh khác nhau.

$$X_N = \frac{X_O - m_X}{s_X} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - Y_{P,i})^2} \quad (2)$$

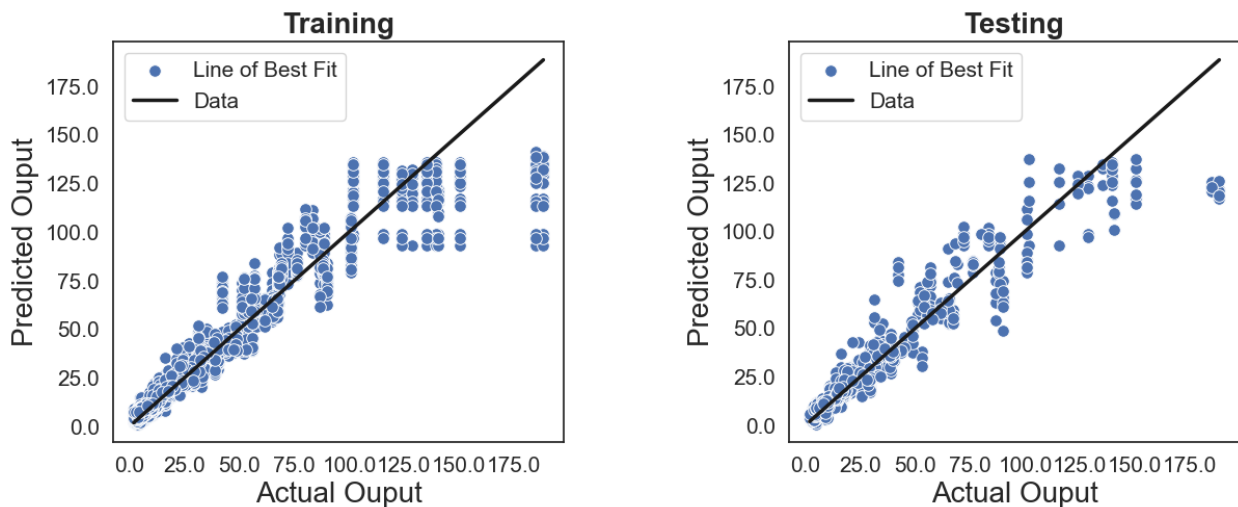
$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \frac{|Y_i - Y_{P,i}|}{Y_i} \quad (3)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_i - Y_{P,i})^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2} \quad (4)$$

trong đó X_N và X_O lần lượt là các biến đã chuẩn hóa và biến ban đầu; m_X và s_X thể hiện giá trị trung bình và độ lệch chuẩn của biến ban đầu; Y_i và $Y_{P,i}$ là kết quả đầu ra thực tế và dự đoán bằng mô hình của mẫu dữ liệu thứ i^{th} ; \bar{Y} là giá trị trung

bình của các biến phụ thuộc đo được trên thực tế; N là số lượng mẫu dữ liệu.

Để huấn luyện và kiểm nghiệm mô hình LightGBM, chúng tôi sử dụng ngôn ngữ lập trình *Python* và thư viện *scikit-learn*. Tập dữ liệu được chia ngẫu nhiên thành hai phần gồm: tập thử nghiệm 15% và tập huấn luyện chiếm 85% tổng số mẫu dữ liệu. Mô hình được chạy ngẫu nhiên 30 lần. Kết quả dự đoán biến dạng từ biến của cấu kiện bê tông cốt thép bằng mô hình LightGBM trong cả giai đoạn huấn luyện (*training*) và thử nghiệm (*testing*) sử dụng dữ liệu của 30 lần chạy được minh họa trên Hình 3. Các tọa độ của các điểm dữ liệu (các chấm màu xanh đen) thể hiện giá trị biến dạng từ biến thực tế và giá trị biến dạng từ biến dự đoán bằng mô hình LightGBM. Các điểm này phân tán càng gần đường thẳng (đường chéo màu đen) thì mô hình dự đoán càng chính xác. Trong hai giai đoạn huấn luyện và thử nghiệm, giá trị trung bình của hệ số xác định R^2 sau 30 lần chạy lần lượt bằng 0.93 và 0.90. Hệ số này càng tiệm cận 1 đơn vị thì chứng tỏ khả năng dự báo của mô hình càng chính xác.



Hình 3. Biểu đồ phân tán các điểm dữ liệu thực tế và dự đoán của mô hình LightGBM trong giai đoạn huấn luyện (*training*) và thử nghiệm (*testing*).

Ngoài ra, kết quả tính toán của mô hình LightGBM cũng được so sánh với hai mô hình khác trong nghiên cứu trước đó gồm mô hình cây hồi quy (*RegTree*) và mô hình XGBoost [23].

Mặc dù mô hình LightGBM kém hơn hai mô hình trên ở giai đoạn huấn luyện, nhưng lại tốt hơn ở giai đoạn kiểm nghiệm. Cụ thể, mô hình LightGBM có thông số *MAPE* tốt hơn mô hình

RegTree (sai số 21.16% so với 24.77%) ở giai đoạn thử nghiệm. Mô hình *LightGBM* cho kết quả dự đoán với độ chính xác cao hơn mô hình cây hồi quy và mô hình *XGBoost* lần lượt là 21.47% và 28.60% ở chỉ số *RMSE* và 8.43% ở thông số R^2 (Bảng 2). Như vậy có thể thấy rằng

mô hình *LightGBM* tỏ ra vượt trội hơn các mô hình khác ở hầu hết các thông số ở giai đoạn thử nghiệm. Do đó, mô hình *LightGBM* có thể được xem là ứng viên phù hợp để ứng dụng vào bài toán dự đoán biến dạng từ biến của các cấu kiện bê tông cốt thép như dầm và sàn một phương.

Bảng 2. So sánh kết quả tính toán của mô hình *LightGBM* với mô hình cây hồi quy và *XGBoost*

Giai đoạn	Thông số	LightGBM		XGBoost		RegTree	
		TB	ĐLC	TB	ĐLC	TB	ĐLC
Huấn luyện	<i>RMSE</i> (mm)	8.47	2.07	6.34	3.34	7.05	1.13
	<i>MAPE</i> (%)	15.31	7.55	8.02	7.53	12.11	1.18
	R^2	0.93	0.04	0.95	0.05	0.95	0.02
Thử nghiệm	<i>RMSE</i> (mm)	9.84	3.22	13.78	5.65	12.53	2.20
	<i>MAPE</i> (%)	21.16	6.23	19.77	10.50	24.77	3.92
	R^2	0.90	0.06	0.83	0.10	0.83	0.08

(trong đó: **TB** – trung bình; **ĐLC** – độ lệch chuẩn)

4. Kết luận

Trong nghiên cứu này chúng tôi ứng dụng mô hình học máy *LightGBM* để giải bài toán dự đoán biến dạng từ biến của các cấu kiện bê tông cốt thép như dầm và sàn một phương trong các công trình xây dựng. Một bộ dữ liệu gồm 217 mẫu thí nghiệm được sưu tầm từ các nghiên cứu thực nghiệm trước đó được sử dụng để huấn luyện và thử nghiệm thuật toán *LightGBM*. 21 yếu tố ảnh hưởng đến biến dạng từ biến được chọn làm biến đầu vào của mô hình *LightGBM*. Kết quả tính toán thử nghiệm cho thấy mô hình *LightGBM* có khả năng dự đoán biến dạng từ biến với độ chính xác cao thể hiện ở các thông số *RMSE*, *MAE*, *MAPE* và R^2 . Do đó, mô hình *LightGBM* có thể được sử dụng như là một công cụ trợ giúp các kỹ sư giải bài toán dự báo biến dạng từ biến của các cấu kiện bê tông cốt thép như dầm và sàn một phương.

Ngoài ra, việc kết hợp mô hình *LightGBM* với một số thuật toán tối ưu hóa cũng là một hướng nghiên cứu mở rộng của đề tài này.

Tài liệu tham khảo

- [1] Espion B. (1988). Long term sustained loading tests on reinforced concrete beams: A Selected Data Base (Part I). *Bulletin du Service Génie Civil* (88-1).
- [2] Gribniak V., Bacinskas D., Kacianauskas R., Kaklauskas G., & Torres L. (2013). Long-term deflections of reinforced concrete elements: accuracy analysis of predictions by different methods. *Mechanics of Time-Dependent Materials* 17(3), 297-313. DOI: 10.1007/s11043-012-9184-y
- [3] Pham A.-D., Ngo N.-T., & Nguyen T.-K. (2020). Machine learning for predicting long-term deflections in reinforced concrete flexural structures. *Journal of Computational Design and Engineering* 7(1), 95-106. DOI: 10.1093/jcde/qwaa010
- [4] Branson D. E. (1963). *Instantaneous and time-dependent deflections of simple and continuous reinforced concrete beams*. Department of Civil Engineering and Auburn Research Foundation. Auburn University.
- [5] Branson D. E. (1977). *Deformation of concrete structures*. McGraw-Hill.
- [6] Bakoss S., Gilbert R., Faulkes K., & Pulmano V. J. M. (1982). Long-term deflections of reinforced concrete beams. *Magazine of Concrete Research* 34(121), 203-212.
- [7] Gilbert R. I. (1999). Deflection calculation for reinforced concrete structures—why we sometimes get it wrong. *Structural Journal* 96(6), 1027-1032.

- [8] Bacinskas D., Kaklauskas G., Gribniak V., Sung W.-P., & Shih M.-H. (2012). Layer model for long-Term deflection analysis of cracked reinforced concrete bending members. *Mechanics of Time-Dependent Materials* (16), 117-127. DOI: 10.1007/s11043-011-9138-9
- [9] Balevičius R., & Dulinskas E. (2010). On the prediction of non-linear creep strains. *Journal Of Civil Engineering And Management* (16), 382-386. DOI: 10.3846/jcem.2010.43
- [10] Gilbert R. I. Deflection Calculation for Reinforced Concrete Structures—Why We Sometimes Get It Wrong. *ACI Structural Journal* 96(6). DOI: 10.14359/779
- [11] Kaklauskas G. (2004). Flexural layered deformational model of reinforced concrete members. *Magazine of Concrete Research - MAG CONCR RES* (56), 575-584. DOI:10.1680/mac.56.10.575.53678
- [12] Kara I. F., & Dundar C. (2009). Prediction of deflection of reinforced concrete shear walls. *Advances in Engineering Software* 40(9), 777-785. DOI: <https://doi.org/10.1016/j.advengsoft.2009.02.002>
- [13] Rodriguez A. (2007). Short- and Long-Term Deflections in Reinforced, Prestressed, and Composite Concrete Beams. *Journal of Structural Engineering* (133), 495-506. DOI: 10.1061/(ASCE)0733-9445(2007)133:4(495)
- [14] Torres L., López-Almansa F., & Bozzo L. (2004). Tension-Stiffening Model for Cracked Flexural Concrete Members. *Journal of Structural Engineering-asce - J STRUCT ENG-ASCE* (130). DOI: 10.1061/(ASCE)0733-9445(2004)130:8(1242)
- [15] Committee A. (2008). *Building code requirements for structural concrete (ACI 318-08) and commentary*. American Concrete Institute.
- [16] Code P. (2005). EUROCODE 2: Design Of Concrete Structures-Part 1-1: General Rules And Rules For Buildings. The European Union.
- [17] Gribniak V., Cervenka V., & Kaklauskas G. (2013). Deflection prediction of reinforced concrete beams by design codes and computer simulation. *Engineering Structures* (56), 2175-2186. DOI: <https://doi.org/10.1016/j.engstruct.2013.08.045>
- [18] Amin G. A. Critical Review. *ACI Structural Journal* 90(4). DOI: 10.14359/9648.
- [19] Oh C. K., & Beck J. L. (2018). A Bayesian Learning Method for Structural Damage Assessment of Phase I IASC-ASCE Benchmark Problem. *KSCE Journal of Civil Engineering* 22(3), 987-992. DOI: 10.1007/s12205-018-1290-1
- [20] Al-Zwainy F. M. S., Zaki R. I. K., Al-saadi A. M., & Ibraheem, H. F. (2018). Validity of artificial neural modeling to estimate time-dependent deflection of reinforced concrete beams. *Cogent Engineering* 5(1), 1-15. DOI: 10.1080/23311916.2018.1477485
- [21] Ghadimi S., & Kourehli S. S. (2017). Multiple crack identification in Euler beams using extreme learning machine. *KSCE Journal of Civil Engineering* 21(1), 389-396. DOI: 10.1007/s12205-016-1078-0
- [22] Sadowski Ł., Nikoo M., Shariq M., Joker E., & Czarnecki S. (2019). The Nature-Inspired Metaheuristic Method for Predicting the Creep Strain of Green Concrete Containing Ground Granulated Blast Furnace Slag. *Materials* 12(2), 293.
- [23] Nguyen H., Nguyen N.-M., Cao M.-T., Hoang N.-D., & Tran X.-L. (2021). Prediction of long-term deflections of reinforced-concrete members using a novel swarm optimized extreme gradient boosting machine. *Engineering with Computers* (38), 1-13.
- [24] Hoang N.-D. (2019). Estimating Punching Shear Capacity of Steel Fibre Reinforced Concrete Slabs Using Sequential Piecewise Multiple Linear Regression and Artificial Neural Network. *Measurement* (137), 58-70. DOI: <https://doi.org/10.1016/j.measurement.2019.01.035>
- [25] Kurtoglu A. E., Gulsan M. E., Abdi H. A., Kamil M. A., & Cevik A. (2017). Fiber reinforced concrete corbels: Modeling shear strength via symbolic regression. *Computers and Concrete* 20(1), 065-075
- [26] G. Ke, Qi M. et al (2017). LightGBM: A highly efficient gradient boosting decision tree [C]. *31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, CA, USA*
- [27] Retrieved from <https://lightgbm.readthedocs.io/en/latest/Features.html>
- [28] Shi H. (2007). *Best-first decision tree learning*. The University of Waikato, Hamilton, New Zealand.
- [29] Espion B. (1988). Long term sustained loading tests on reinforced concrete beams. *Bulletin du Service Génie Civil* (88-1).